

УДК 004.93

DOI: 10.15587/1729-4061.2018.139997

## Выявление шаблонов дыхания человека с помощью глубоких сверточных нейронных сетей

А. И. Петренко, Р. В. Кислий, И. О. Письменный

Запропоновано метод розпізнавання в реальному часі типів (шаблонів) дихання пацієнта з ціллю моніторингу його стану і загроз для здоров'я, що є частковим випадком проблеми розпізнавання людських активностей (HAR). Метод заснований на застосуванні глибинного машинного навчання з допомогою згорткової нейронної мережі (CNN) для класифікації швидкості руху його грудної клітки. Показано, що прийняті при цьому рішення узгоджуються з технологією мобільної медицини (mHealth) з використанням натільних датчиків і смартфонів для оброблення їх сигналів в якості обчислювальних edge-вузлів, але CNN відкривають важливі додаткові можливості з підвищенні якості оброблення сигналів датчика-акселерометра в умовах наявності перешкоджаючих сигналів (шумів) від інших джерел та інструментальних похибок пристрою. Вхідні сигнали попередньо нормалізується щодо осі обертання, щоб зменшити вплив шуму на результати, оскільки акселерометр вимірює гравітаційне прискорення ( $g$ ) і лінійне прискорення ( $a$ ). Запропоновано спосіб перетворення одновимірних сигналів (1d) акселерометра в двовимірні (2d) графічні зображення, які оброблюються за допомогою CNN із декількома обробними шарами, завдяки чому точність визначення шаблону дихання в різних ситуаціях для різних фізичних станів пацієнтів зростає в порівнянні з випадком, коли двовимірні перетворення сигналів акселерометра не вживаються. При цьому зростання точності (або якості) визначення різних типів дихання відбувається при збереженні достатньої швидкості процедур запланованого методу, що дозволяє проводити класифікацію типів дихання в реальному часі. Дану методику було випробувано в якості компоненту Body Sensor Network (BSN) і встановлено високу точність (88%) визначення стану дихання пацієнта, що в поєднанні з даними контексту, отриманими з інших вузлів BSN, дозволяє визначати стани пацієнтів і передбачати загострення їх респіраторних хвороб

Ключові слова: акселерометр, глибинне навчання, шаблони дихання, згорткові нейронні мережі, машинне навчання

### 1. Введение

Необходимость диагностики и наблюдения за различными респираторными заболеваниями или их обострениями способствовали развитию различных методов измерения дыхания. В то же время недавнее развитие технологий IoT и глубинного обучения [1] создало возможность объединить их и создать систему

непрерывного наблюдения. Такая система может использоваться для обнаружения или прогнозирования и предотвращения обострений опасных состояний при различных повседневных действиях человека (таких как ходьба, сон и другие виды деятельности, которые изменяют физическое состояние).

Так как количество загрязнения воздуха в городах постоянно увеличивается, также увеличивается количество людей с проблемами дыхания. Поэтому исследуется возможность постоянного мониторинга дыхания с применением акселерометра, который не мешает повседневной деятельности. Использование такой системы позволит распознавать текущее состояние человека, а также предсказывать потенциальные обострения.

Автоматическое обнаружение и распознавание шаблонов дыхания человека для мониторинга состояния здоровья без каких-либо неудобных датчиков, которые делают невозможными постоянные измерения, было ключевой проблемой для технологий, использующих анализ дыхания и поведения человека. В результате, появилось решение для обнаружения частоты дыхания, основанное на сигналах, полученных от разных носимых датчиков в режиме реального времени. При непрерывном измерении скорости дыхания сигналы, полученные от датчиков, носимых на теле, намного более предпочтительны, чем сигналы, полученные от внешних датчиков (например, тепловизора, датчика давления и т. д.), даже если последние точнее. Основные причины перечислены ниже.

- Камеры, спирометры или другие датчики, не подверженные износу, страдают от воздействий окружающей среды и сложности использования. В то же время датчики, носимые на теле, – нет, поэтому они могут выполнять измерения намного чаще и даже непрерывно, что обеспечивает более точные результаты.

- Датчик на теле получает только целевые сигналы, в то время как сигналы внешних датчиков могут искажаться информацией от других объектов окружающей среды. Это приводит к необходимости более сложной предварительной обработки сигнала (которая не всегда возможна).

- Сигналы от акселерометра могут использоваться совместно с сигналами других носимых датчиков для достижения большей точности или получения дополнительной контекстной информации, которая может использоваться для распознавания более сложных образов. Например, более частая частота дыхания во время бега должна считаться нормальной, в отличие от нормы в спокойном состоянии. Более того, этот контекст имеет решающее значение для различения различных хронических состояний. Например, нормальное дыхание составляет около 12 вдохов в минуту, или 6 л/мин, в то время как люди с респираторными заболеваниями дышат быстрее и глубже. Такое отклонение также проявляется для многих других распространенных хронических заболеваний.

Проблема обнаружения шаблонов дыхания может рассматриваться как частный случай задачи распознавания человеческой активности. Ключевым фактором, который влияет на качество решения этой задачи, является хорошая предварительная обработка сигналов, собранных с датчиков. Обычно такая

обработка включают в себя базовое преобразование сигнала (например, вейвлет-преобразование или преобразование Фурье) или интерпретацию необработанных сигналов с использованием статистических методов, таких как дисперсия и среднее значение [2]. Несмотря на то, что эти процедуры широко используются во многих задачах с временными рядами, они не зависят от задачи и поэтому могут также использоваться для распознавания шаблонов дыхания.

Таким образом, разработка метода непрерывного измерения скорости дыхания и определения шаблона дыхания путем комбинирования использования предварительной обработки сигналов и сверточных нейронных сетей (CNN) в реальном времени является актуальной задачей для практического исследования.

## **2. Анализ литературных данных и постановка проблемы**

Для измерения дыхания человека существует множество различных методов. Например, использование спирометра можно назвать идеальным решением для этой задачи, так как гарантируется 100 % точность измерения [3]. Тем не менее, спирометр не может использоваться постоянно, так как пациент должен дышать в него, что невозможно делать непрерывно в повседневной жизни.

Также существует много косвенных методов анализа дыхания, например, с определением концентрации кислорода в крови [4]. Однако, поскольку концентрация кислорода изменяется довольно медленно, этот метод не применим для обнаружения смены дыхания в реальном времени, а, следовательно, и опасного состояния пациента [5]. Кроме того, шаблоны дыхания могут быть обнаружены с помощью звуков трахеи. Этот метод хорош для выделения глубокого дыхания или дыхания во время активности, такой как бег. Тем не менее, такой метод не очень хорош для обнаружения разных шаблонов в спокойных состояниях, потому что звук меняется очень незначительно. Так же, из-за шумов, создаваемых окружающей средой или другими движениями человека, очень сложно обнаружить дыхательный звук и его изменения [6].

Другой способ измерения дыхания был предложен в работе [7]. Используя датчик объема на базе пьезоэлектрического преобразователя, помещенный на грудную клетку, измеряют изменение ее окружности во время дыхания. Известны и другие методы, требующие большого количества дополнительных датчиков или медицинского оборудования, которые довольно точны, но не приспособлены для непрерывного и ежедневного использования.

С другой стороны, акселерометры, носимые на теле, способны измерять угловые изменения во время дыхания, оценивая ускорение движения грудной клетки, а значит и скорость дыхания [8]. Для этого в работе [8] применяется адаптивный полосовой фильтр с использованием анализа главных компонент (PCA) в сочетании с цифровой обработкой сигналов. Чтобы улучшить качество сигнала от большинства доступных акселерометров (например, на смартфоне пользователя или других доступных для ношения устройствах) в работе [9] предлагается использование фильтра Калмана.

Основываясь на характере сигнала дыхания, мы рассматриваем его как комбинацию нескольких основных непрерывных движений, представленных сигналами акселерометра и гироскопа (который не оказал влияния на точность в ходе эксперимента, и не был использован в дальнейшем). Основная проблема использования такого представления для обнаружения шаблонов дыхания заключается в извлечении этого шаблона из сложного сигнала, во время повседневной деятельности пользователя.

Поскольку вычислительная мощность, доступная на периферийных устройствах потребительского рынка, достигла 16,6 GFLOPS, можно использовать глубинное обучение на умных сенсорах или пользовательском устройстве. И соответственно доставлять уведомления и рекомендации с минимальной задержкой и даже автономно, не завися от сервера или наличия соединения с сетью.

В то же время извлечение точных сигналов из зашумленных сырых данных акселерометра все еще довольно сложная задача. Огромное количество различных рутинных действий, которые выполняются людьми, затрудняет их обнаружение.

### **3. Цель и задачи исследования**

Целью работы является определение 6 различных типов шаблонов дыхания, зависящих от активности действий человека.

Для достижения цели были поставлены следующие задачи:

- сформировать набор данных для проведения эксперимента;
- осуществить предварительную подготовку и очистку данных;
- определить шаблоны дыхания, используя CNN и собранные данные.

### **4. Сбор данных, их предварительная обработка и построение нейронной сети**

Для проверки предлагаемых решений и гипотез нужно вначале сформировать набор данных. С этой целью разработано приложение для Android, которое собирает данные с акселерометра, прикрепленного к груди пользователя, и передает данные на смартфон, используя Bluetooth с частотой дискретизации 30 Гц (30 значений в секунду). Для получения различных образцов дыхания данные обновляются после различных физических действий пациента, которые включают спокойное дыхание, дыхание после отжимания, дыхание во время бега, глубокое дыхание, быстрое дыхание, дыхание с задержкой. Акселерометр был прикреплен над ребрами под соском (рис. 1), используя скотч-ленту. Предварительно путем изменения положения акселерометра на груди было установлено, что это положение дает самую большую амплитуду движущейся грудной клетки и, как следствие, самый чистый сигнал дыхания. Кроме того, то же место для акселерометра было использовано и в работе [10].




Рис. 1. Общая схема системы и место крепления акселерометра

Чтобы получить более сбалансированные данные, исследовалась тестовая группа из 8 пользователей (по 4 человека каждого пола), четыре из них были 25-летними, два – 40-летними и еще два – 55-летними. У всех пользователей, включенных в тестовую группу, был средний уровень физической активности. Измерения проводились с помощью смартфона с созданным приложением и датчиком, прикрепленным к грудной клетке. Каждое действие записывалось в течение 5 минут (для записи после отжиманий данные записывались в течение 30 секунд, а затем повторялась серия из 10 отжиманий). При записи данных акселерометра с частотой 30 Гц (30 значений в секунду) за 5 минут фиксируются 9000 значений для каждого вида активности и для каждого человека. Таким образом, полный набор данных включает в себя 432 000 значений. Поскольку данные, снятые с одного человека, используются полностью для тестирования набора данных, предполагается, что этого достаточно для проверки методов и гипотез.

Данные, собранные с датчика, имеют следующую структуру: временную метку (в формате Unix с миллисекундами), ускорение по оси x, ускорение по оси Y, ускорение по оси z. Например:

*1486291984848/1.61407470703125/-9.95855712890625/ 2.83917236328125.*

После сеанса записи данные сохранялись на мобильном телефоне, а затем размечались добавлением столбца активности. Полученный набор данных разделялся на части для тестирования и обучения. Поскольку измерения велись с обобщенными данными, описывающими деятельность человека, то последующей проверки работоспособности модели сохранялись отдельно индивидуальные данные, собранные от одного из участников. Поскольку у разных людей

различный объем легких, движение грудной клетки и другие физиологические параметры, это означает, что если методика справедлива для человека, не включенного в тестовую группу, то ее можно использовать применительно и к другим людям.

Сверточные нейронные сети успешно используются для задач распознавания изображений. [11]. Акселерометр же производит одномерные сигналы в отличие от двумерных изображений. Поэтому было принято решение преобразовать полученный сигнал в 2d-изображение и сравнить результаты с традиционным подходом, использующим 1d сигнал.

Преобразование 1d-сигнала в 2d-изображение можно выполнить несколькими способами, в частности, использованием нормализации и преобразования в матрицу. Используя этот подход, образцы сигнала внутри окна среза преобразуются в изображение серого цвета со шкалой 0–255. В этом изображении более темный цвет обозначает большую амплитуду в исходном сигнале, а координаты пикселя –  $(i, j)$  матрицы  $M \times N$  для каждого  $n$ -го образца сигнала, где

$$i = \frac{N}{M} \text{ и } j = \frac{N}{M}. \quad (1)$$

На рис. 2 иллюстрируется этот подход.



Рис. 2. Преобразование сигнала в матрицу [12]

Этот подход прост и удобен в работе, так как он не требует большой вычислительной мощности, но, в то же время, имеет очень большой недостаток: он очень восприимчив к шуму и аномалиям, поэтому он не может использоваться для наших данных.

Как показано в работе [7], альтернативой может быть подход, когда сигналы складываются вместе последовательно по строкам (stacking) в виде изображения, что позволяет каждой последовательности сигналов коррелировать с другими последовательностями. Затем производится 2d дискретное преобразование Фурье (DFT), а его величина представляет собой изображение, которое используется в качестве входного сигнала CNN. Этот подход модифицируется включением процедуры нормализации сигналов перед стекингом в одно изображение.

Поскольку сам акселерометр измеряет гравитационное ускорение (g) и линейное ускорение (a), то по мере перемещения людей в разных направлениях акселерометр вращается, и каждая ось измеряет разное ускорение (g или a). Чтобы непрерывно измерять движение на оси a и уменьшать шум (отключить нерелевантные измерения), необходимо нормализовать значения измерений.

Угол  $\theta_t$  показывает, как вращение оси во времени от  $t-1$  до  $t$ :

$$\theta_t = \cos^{-1}(a_t \times a_{t-1}), \quad (2)$$

где a – вектор значений за время. Чтобы уменьшить влияние шума на результаты, каждое наблюдение нормализуется на угол вращения  $\theta_t$ , в момент времени  $t$ . Таким образом, нормализованный сигнал будет выглядеть так:

$$a_{xt} = a_x \times \theta_t, \quad a_{yt} = a_y \times \theta_t, \quad a_{zt} = a_z \times \theta_t. \quad (3)$$

Поскольку используется метод скользящего окна, то с целью уменьшения шума применена функция H(n) окна Хэмминга для нормализованного сигнала.

В результате алгоритм предварительной обработки необработанного входного сигнала выглядит следующим образом:

1. Нормализовать входной сигнал относительно оси вращения, как описано выше.
2. Применить функцию окна Хэмминга на уже нормализованном сигнале.
3. Преобразовать сигнал из нашего окна, с помощью алгоритма из [7].
4. Примените DFT на полученном изображении.

После выполнения этого подхода на данных из датчиков результаты передаются в CNN. Процесс обработки сигнала показан на рис. 3.

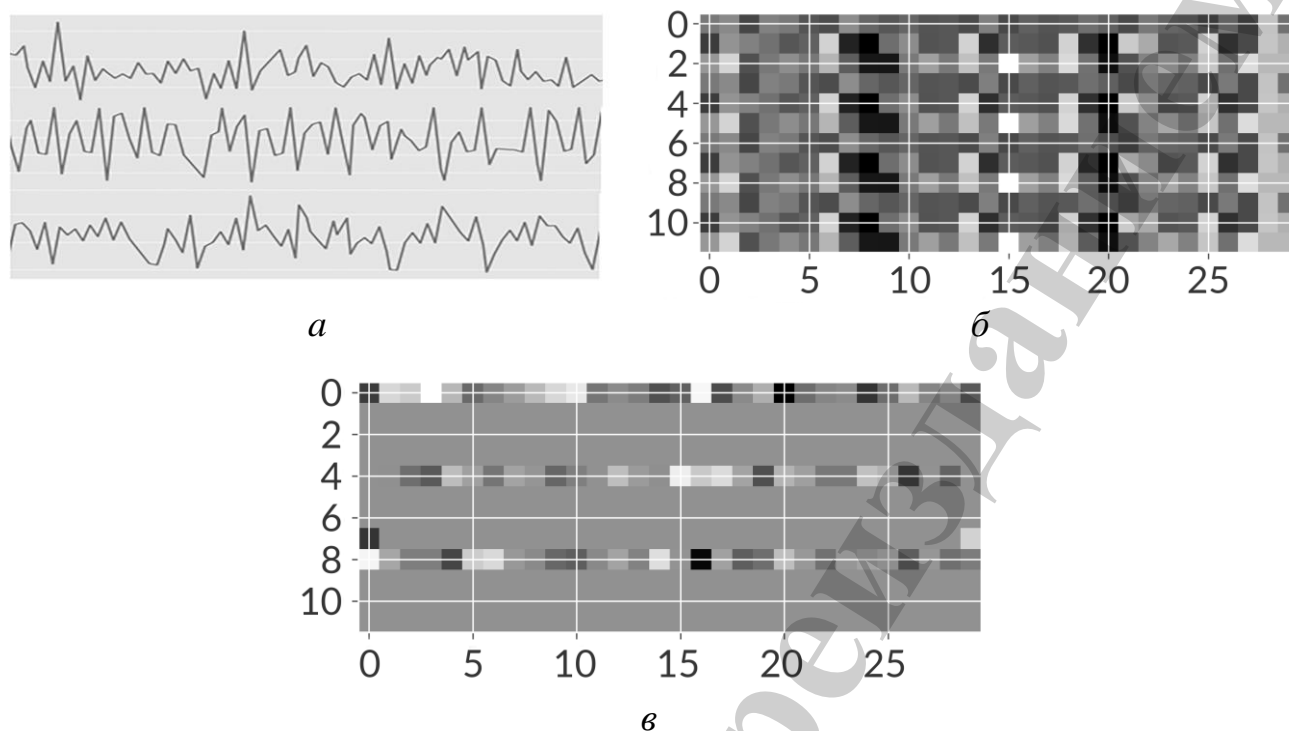


Рис. 3. Обработка сигнала акселерометра: *а* – входящий сигнал; *б* – сигнальный рисунок; *в* – спектр амплитуды

Чтобы оценить, как предложенный метод предварительной обработки улучшает качество обнаружения шаблона, проведено его сравнение с использованием CNN для нормализованного сигнала в качестве входных данных [13].

Сверточные нейронные сети (CNN) являются одним из самых надежных, гибких и широко используемых методов обнаружения шаблонов сигналов. В более высоких слоях обнаруживают разные особенности сигналов (например, в данном случае для характеристики каждого движения груди). Более глубокие слои получают схемы сигналов в представлении высокого уровня (для нескольких движений). Каждый уровень может иметь несколько операторов свертки или объединения, поэтому несколько шаблонов, обучаемых из разных аспектов, могут использоваться вместе. В результате этого могут обнаруживать более сложные шаблоны по сравнению с другими традиционными статистическими методами, такими как Support Vector Machines (SVN), Random Forest или другие [14].

Для проведения экспериментов использовалась стратегия скользящего окна для обработки сигналов как применительно к исходному сигналу, так и для случая генерации изображений из входного сигнала. Основная идея скользящего окна состоит в том, чтобы разделить сигнал временных рядов на короткие фрагменты.

Когда данные снимаются с частотой 30 наблюдений в секунду, то размер скользящего окна, равный 90 выборкам, соответствует 3 секундам наблюдений, а размер шага окна, равный 32 выборкам, составляет 1,06 секунды. Большой или



меньший размер шага может использоваться либо для увеличения точности (меньше), либо для уменьшения необходимой вычислительной мощности (больше), или потребляемой энергии, что является критическим параметром. Поэтому должен быть найден компромисс между точностью и количеством вычислений.

Так как основная цель исследования – выявить тип дыхания в реальном времени с минимальной задержкой, более высокая вычислительная стоимость может быть проблемой, вызывающей большие задержки (особенно на не очень мощных устройствах). Для первого эксперимента с входными данными в виде нормализованного сигнала генерируются сегменты окон и в каждый компонент сигнала добавляется третье измерение, чтобы входной вектор для CNN содержал полные сегменты, входной сегмент, вход канала (рис. 4).

Для первого эксперимента с входными данными в виде нормализованного сигнала генерируются сегменты окон и добавляются в каждый компонент сигнала в виде третьего измерения, чтобы входной вектор для CNN был следующего вида: [полные сегменты, входной сегмент, вход канала].




Рис. 4. Архитектура CNN для первого эксперимента

Поскольку сигнал является одномерным и для него предусмотрена 1d-свертка, то необходимо изменить сформированные окна, которые будут нормализованы до высоты 1.

Для второго эксперимента с стекингом и обработкой сигналов как графического изображения вводятся изменения. Поскольку имеются 3 последовательности входных сигналов, то в соответствии с используемым алгоритмом каждый сигнал повторяется четыре раза. В результате чего размер изображения входного сигнала равен  $12 \times 32$ , где параметр 32 определяется выбранным размером окна.

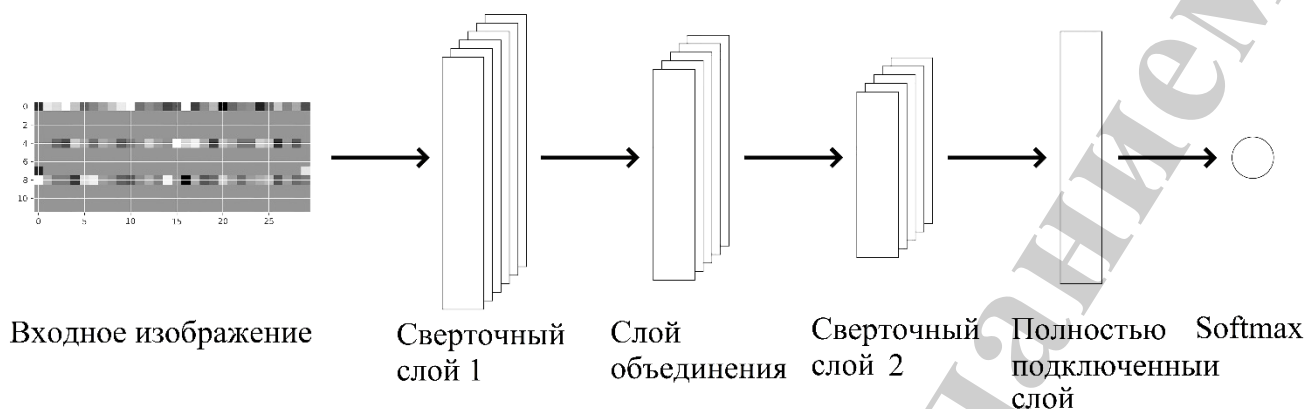


Рис. 5. Архитектура CNN для предварительно обработанного входного сигнала

Модель состоит из одного слоя свертки, за которым следует слой максимального объединения (pooling layer), и еще один слой свертки. После этого модель содержит полностью подключенный слой (fully-connected layer), который подключен к слою Softmax (в задачах обнаружения классификации или шаблона последний слой CNN обычно представляет собой слой Softmax – многолинейная логистическая регрессия). Описанная архитектура нейронной сети показана на рис. 4.

CNN обучаются с использованием итеративной оптимизации с помощью алгоритма обратного распространения (backpropagation). Наиболее широко используемым методом оптимизации является стохастический градиентный спуск (SGD) и оптимизатор YellowFin [15]. В эксперименте использовался оптимизатор YellowFin, так как он имеет самую низкую ошибку обучения и динамическую скорость обучения, а SGD обычно накапливает ошибку после 300 эпох [15].

Функция стоимости обучения нашей CNN-архитектуры – это Softmax с L2-регуляризацией. В работе применена выпрямленная линейная единица (ReLU) как функция активации (activation function). Гиперпараметрами CNN являются:

- количество и типы слоев,
- размер фильтров для свертки и шаг свертки для каждого сверточного слоя,
- размер области объединения и шаг объединения для каждого слоя объединения,
- количество единиц для каждого полностью подключенного слоя.

На основе приведенных выше операторов построена CNN, показанная на рис. 5. Все слои CNN можно сгруппировать в пять разделов, как описано ниже.

Первый слой свертки имеет размер фильтра и глубину 60 (количество каналов получают как выход из слоя свертки). Размер фильтра слоя объединения устанавливается равным 20 с шагом 2. Затем слой свертки берет входной слой с максимальным уровнем объединения, применяя фильтр размером 6, и будет иметь

десятую часть глубины на уровне максимального объединения. После этого выход сглаживается для вектора входа полностью подключенного слоя.

В полностью подключенном слое (это может быть определено конфигурацией) размещены 1000 нейронов. В этом слое используется функция гиперболического тангенса  $\tanh$  для нелинейности. Слой Softmax определяется для вывода вероятностей меток класса. Функция отрицательного логарифмического правдоподобия (negative log likelihood) [16] минимизируется с помощью стохастического оптимизатора спуска градиента (SGD).

Использование исходного ввода (с некоторой предварительной обработкой) в архитектурах CNN является нормальной ситуацией для приложений глубинного обучения в предметной области компьютерного зрения. Однако CNN, как правило, не настолько эффективны с 1-мерным сигналом и для проведения второго эксперимента осуществляется преобразование сигнала в 2D -изображение.

Для второго эксперимента с сигналом, преобразованным в 2D-изображение, первый и второй сверточные слои CNN (рис. 5) выполняют двумерную свертку на своих входах. Карта вывода формируется следующим образом:

$$y_i = \left( 1 + \exp \left( b_j + \sum_i k_{ij} \times x_i \right) \right)^{-1}, \quad (4)$$

где  $k_{ij}$  – сверточное ядро на  $i$ -ом входном отображении  $x_i$  для генерации  $j$ -го выходного отображения  $y_j$ ,  $b_j$ .

Слой объединения организован как метод подвыборки. Выход  $y_i$  вычисляется путем принятия средних значений неперекрывающихся областей  $x_i$  с фильтром  $m \times m$

$$y_i(r, c) = \frac{\sum_{p=1}^m \sum_{q=1}^m x_i(r \times m + p, c \times m + q)}{m^2}, \quad (5)$$

где  $r, c$  – координаты пикселя  $y_i$ .

После полностью подключенного слоя получают 1D-вектор  $f$  на выходе. Функция Softmax применяется для определения вероятности каждого класса, что соответствует вероятности каждого из 6-ти различных типов дыхания:

$$p(s) = \frac{g_s}{\sum_{j=1}^{N_a} g_j}, \quad g_j = \max \left( 0, \sum_i f_i \times w_{ij} + h_j \right), \quad (6)$$

где  $w$  и  $h$  – коэффициенты функции Softmax, а  $s$  – один из предсказуемых классов.

## 5. Оценка и сравнение точности выделения шаблонов дыхания

Основной проблемой для оценки результатов была проблема дисбаланса классов. Гораздо легче регистрировать низкую физическую активность для многих, особенно старших, людей (которые являются основной целевой группой разрабатываемого решения). В результате чего было получено гораздо больше данных, записанных для спокойного дыхания, чем для других типов. Чтобы уменьшить влияние несбалансированных классов, можно использовать различные сбалансированные группы данных для каждой эпохи в оптимизаторе YellowFin [17].

Для оценки результатов построенной модели вычислялись несколько показателей:

- Точность, отзыв (precision, recall);
- F1;
- Потеря обучения (training loss);
- Точность обучения (accuracy).

Точность тестирования проверялась, используя записи от человека, который не был добавлен в учебный набор данных, что помогло избежать переобучения на конкретных людях.

Поскольку в работе классифицируются 6 разных классов (шаблонов дыхания) с двоичными метриками [18], то необходимо представлять эту классификацию как 6 различных бинарных классификаций, где каждый раз один класс считается положительным, а все остальные классы помечены как отрицательные (классификация один-против всех) [19]. Этому способствует построение матрицы неурядиц (confusion matrix), приведенной ниже на рис. 6 для лучшего понимания производительности построенной модели.

Из табл. 1 видно, что после 40 эпох обучения построенная модель явно начала переобучаться, в результате чего достигается уровень 84 % точности модели. То же самое можно увидеть в табл. 2, где для предварительно обработанного сигнала показана точность 88 %, что, несомненно, лучше, чем в предыдущем случае, но все же далеко от совершенства.

Таблица 1

Метрики с использованием нормализованного сигнала

Количество эпох	F1 score	Recall	Precision	Training Accuracy	Training Loss	Testing Accuracy
Epoch 0	0.615	0.67	0.6	0.67	7.82	0.45
Epoch 10	0.839	0.881	0.825	0.881	3.63	0.765
Epoch 20	0.942	0.947	0.941	0.947	2.653	0.818
Epoch 30	0.969	0.971	0.97	0.971	2.179	0.834

Epoch 40	0.976	0.977	0.977	0.977	1.81	0.843
Epoch 50	0.98	0.98	0.98	0.98	1.709	0.836

Таблица 2

Метрики с использованием преобразования сигнала в рисунок

Количество эпох	F1 score	Recall	Precision	Training Accuracy	Training Loss	Testing Accuracy
Epoch 0	0.515	0.57	0.5	0.57	5.73	0.37
Epoch 10	0.727	0.732	0.749	0.76	4.02	0.65
Epoch 20	0.919	0.918	0.925	0.95	2.756	0.729
Epoch 30	0.959	0.951	0.939	0.961	2.217	0.8
Epoch 40	0.973	0.97	0.981	0.98	1.756	0.88
Epoch 50	0.983	0.983	0.983	0.983	1.69	0.873

Таблица 3

Матрица неурядиц CNN для необработанного сигнала

Типы дыхания	Спокойное дыхание	Дыхание после отжиманий	Глубокое дыхание	Быстрое дыхание	Дыхание во время бега	Дыхание с задержкой
Дыхание с задержкой	0.97	0.028	0	0	0	0
Дыхание во время бега	0.026	0.64	0.33	0	0	0
Быстрое дыхание	0	0.2	0.75	0	0	0.055
Глубокое дыхание	0	0	0	0.65	0.33	0.014
Дыхание после отжиманий	0	0	0	0.24	0.76	0
Спокойное дыхание	0	0.051	0.029	0	0	0.92

Таблица 4

Матрица неурядиц CNN для сигнала, конвертируемого в рисунок

Типы дыхания	Спокойное дыхание	Дыхание после отжиманий	Глубокое дыхание	Быстрое дыхание	Дыхание во время бега	Дыхание с задержкой
Дыхание с задержкой	0.95	0.041	0.014	0	0	0
Дыхание во время бега	0.021	0.73	0.23	0.021	0	0
Быстрое дыхание	0	0.19	0.72	0.017	0.069	0
Глубокое дыхание	0	0.015	0.015	0.71	0.26	0
Дыхание после отжиманий	0	0.043	0	0.19	0.77	0
Спокойное дыхание	0	0	0.029	0	0	0.97

Как видно из матриц неурядиц, приведенных в табл. 3, 4, предложенный подход довольно точно может определить спокойное дыхание и дыхание с задержкой, в то время как при попытке классифицировать другие типы фиксируется много ошибочных срабатываний. Особенно много ошибочной классификации между бегом и быстрым дыханием, а также между отжиманиями и глубоким дыханием. Это можно объяснить тем, что сигналы от дыхания с задержкой и спокойным дыханием с меньшей вероятностью сопровождаются другими действиями, связанными с движением грудной клетки, и поэтому более уникальны. В то время как при быстром дыхании и беге (а также отжимании и глубоком дыхании), движения грудной клетки более идентичные и, кроме того, снимаемый сигнал загрязнен огромным количеством данных физической активности, из-за чего дыхательное движение грудной клетки труднее распознать.

## 6. Обсуждение результатов использования CNN для определения шаблонов дыхания

Предложенный метод распознавания шаблонов дыхания и предложенная предварительная обработка данных позволяет CNN фиксировать шаблоны сигнала акселерометра в разных ситуациях и временных масштабах с использованием двумерных сверток для получения высокоуровневых характеристик для

обнаружения паттерна. Для доказательства того, что этот метод работает лучше, чем использование просто исходного сигнала в качестве входных данных, было проведено сравнение этих двух подходов при использовании одного и того же набора данных.

Все определенные шаблоны унифицированы для прогнозирования известных шаблонов дыхания. Ключевыми моментами, которые предложены в текущем методе, являются:

- использование только одного нательного датчика для обнаружения шаблона дыхания;
- преобразование сигнала акселерометра в 2d-изображение с использованием предыдущей нормализации относительно вращения оси;
- использование методов глубинного обучения для создания модели, независимой от процедур извлечения характеристик;
- возможность использования этого подхода для определения других видов действий человека.

Используя предложенный подход, можно определять шаблоны дыхания с точностью 88 %, что можно считать хорошим результатом для использования только одного датчика.

В тоже время необходимо указать на ограничения и недостатки исследуемого подхода:

- при добавлении новых шаблонов необходимо изменять набор входных данных для обучения нейронной сети, а это приведёт к увеличению размера окончательной модели, что может затруднить ее использование на мобильных устройствах;
- если разные шаблоны дыхания будут очень похожи друг на друга, возрастает вероятность ошибки распознавания.

Также интересно объединить полученные данные с данными других нательных датчиков (например, измерения сердечного ритма) для прогнозирования более сложных действий человека, что может стать многообещающей темой для будущих исследований. Например, комбинирование значения сердечного ритма и текущего состояния дыхания человека позволит более точно прогнозировать возможность появления приступа астмы. Важно отметить, что при добавлении данных от других датчиков целесообразно исследовать применимость других архитектур нейронных сетей кроме CNN.

## **7. Выводы**

1. Чтобы исследовать возможность автоматической классификации типов (шаблонов) дыхания пациентов нужен входной массив данных, учитывающий разные состояния пациентов. Такой набор данных был собран с помощью нательного акселерометра, он содержит 432 000 измерений различных типов дыханий 8-ми пациентов разного возраста в различных их состояниях (спокойное дыхание, глубокое, быстрое, с задержкой, после отжимания, после бега). Это

определяющий фактор для формирования входного массива данных, учитывающий разные состояния пациентов. Был также дополнительно сформирован входной контрольный массив данных, не участвующий в машинном обучении сети, для проверки предложенного метода распознавания шаблонов дыхания.

2. Для получения графического представления сформированного набора данных, необходимого для эффективного использования CNN, предложено преобразовывать 1d сигналы акселерометра в 2d графическое изображение с использованием нормализации и преобразования в матрицу. Входной сигнал предварительно нормализуется относительно оси вращения, чтобы уменьшить влияние шума на результаты, так как акселерометр измеряет гравитационное ускорение ( $g$ ) и линейное ускорение ( $a$ ). Используется также идея скользящего окна, состоящая в разделении сигнала временных рядов на короткие фрагменты. Значения сигнала внутри окна обрабатываются дискретным преобразованием Фурье (DFT), с помощью которого получают изображение серого цвета со шкалой 0-255, которое используется в качестве входного сигнала CNN.

3. Предложенный метод классификации шаблонов дыхания с помощью CNN сети может быть реализован в двух модификациях. Первый вариант рассчитан на обработку 1d входных данных и основан на взаимодействии слоев с 1d сверткой, а второй базовый вариант – с взаимодействием слоев с 1d и 2d свертками через слой объединения. Проведенные экспериментальные исследования с указанными вариантами показали преимущества второго варианта в точности распознавания шаблонов дыхания, достигающей на выбранном массиве данных показателей 88 %. Этим подтверждается полезность предложенной предварительной обработки сигнала при использовании глубинного обучения в задаче распознавания шаблонов дыхания пациентов.

## Литература

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. URL: <http://www.deeplearningbook.org/>
2. Huynh T., Schiele B. Analyzing features for activity recognition // Proceedings of the 2005 joint conference on Smart objects and ambient intelligence innovative context-aware services: usages and technologies – sOc-EUSAI '05. 2005. doi: <https://doi.org/10.1145/1107548.1107591>
3. SpiroSmart: Using a Microphone to Measure Lung Function on a Mobile Phone / Larson E. C., Goel M., Boriello G., Heltshe S., Rosenfeld M., Patel S. N. URL: <https://homes.cs.washington.edu/~shwetak/papers/SpiroSmart.CR.Final.pdf>
4. Shephard R. J. The oxygen cost of breathing during vigorous exercise // Quarterly Journal of Experimental Physiology and Cognate Medical Sciences. 1966. Vol. 51, Issue 4. P. 336–350. doi: <https://doi.org/10.1113/expphysiol.1966.sp001868>



5. Rakhimov A. Abnormal breathing pattern causes asthma and attacks. URL: <https://www.worldwidehealth.com/health-article-Abnormal-breathing-pattern-causes-asthma-and-attacks.html>
6. Movement analysis of the chest compartments and a real-time quality feedback during breathing therapy / Fekr A. R., Janidarmian M., Radecka K., Zilic Z. // In Proceedings of the 2005 Joint Conference on Smart Objects and Ambient Intelligence: Innovative Context-aware Services: Usages and Technologies. 2005.
7. Respiratory Rate and Flow Waveform Estimation from Tri-axial Accelerometer Data / Bates A., Ling M. J., Mann J., Arvind D. K. // 2010 International Conference on Body Sensor Networks. 2010. doi: <https://doi.org/10.1109/bsn.2010.50>
8. Phonspirometry for noninvasive measurement of ventilation: methodology and preliminary results / Que C.-L., Kolmaga C., Durand L.-G., Kelly S. M., Macklem P. T. // Journal of Applied Physiology. 2002. Vol. 93, Issue 4. P. 1515–1526. doi: <https://doi.org/10.1152/jappphysiol.00028.2002>
9. Estimation of Respiration Rate from Three-Dimensional Acceleration Data Based on Body Sensor Network / Liu G.-Z., Guo Y.-W., Zhu Q.-S., Huang B.-Y., Wang L. // Telemedicine and e-Health. 2011. Vol. 17, Issue 9. P. 705–711. doi: <https://doi.org/10.1089/tmj.2011.0022>
10. Improvement of Dynamic Respiration Monitoring Through Sensor Fusion of Accelerometer and Gyro-sensor / Yoon J.-W., Noh Y.-S., Kwon Y.-S., Kim W.-K., Yoon H.-R. // Journal of Electrical Engineering and Technology. 2014. Vol. 9, Issue 1. P. 334–343. doi: <https://doi.org/10.5370/jeet.2014.9.1.334>
11. Performance evaluation of a tri-axial accelerometry-based respiration monitoring for ambient assisted living / Jin A., Yin B., Morren G., Duric H., Aarts R. M. // 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 2009. doi: <https://doi.org/10.1109/iembs.2009.5333116>
12. Uddin J., Van D. N., Kim J.-M. Accelerating 2D Fault Diagnosis of an Induction Motor using a Graphics Processing Unit // International Journal of Multimedia and Ubiquitous Engineering. 2015. Vol. 10, Issue 1. P. 341–352. doi: <https://doi.org/10.14257/ijmue.2015.10.1.32>
13. Wireless breathing system for long term telemonitoring of respiratory activity / Ciobotariu R., Adochiei F., Rotariu C., Costin H. // Advanced topics in electrical engineering, Proceedings of the 7th international symposium ATEE. 2011. P. 635–638.
14. Bulling A., Blanke U., Schiele B. A tutorial on human activity recognition using body-worn inertial sensors // ACM Computing Surveys. 2014. Vol. 46, Issue 3. P. 1–33. doi: <https://doi.org/10.1145/2499621>
15. Zhang J., Mitliagkas I. YellowFin and the Art of Momentum Tuning. URL: <https://arxiv.org/pdf/1706.03471.pdf>
16. Deep Convolutional Neural Networks On Multichannel Time Series For Human Activity Recognition / Yang J. B., Nguyen M. N., San P. P., Li X. L.,

Krishnaswamy S. // Proceeding IJCAI'15 Proceedings of the 24th International Conference on Artificial Intelligence. 2015. P. 3995–4001.

17. Convolutional Neural Networks for Human Activity Recognition using Mobile Sensors / Zeng M., Nguyen L. T., Yu B., Mengshoel O. J., Zhu J., Wu P., Zhang J. // Proceedings of the 6th International Conference on Mobile Computing, Applications and Services. 2014. doi: <https://doi.org/10.4108/icst.mobicase.2014.257786>

18. Jiang W., Yin Z. Human Activity Recognition Using Wearable Sensors by Deep Convolutional Neural Networks // Proceedings of the 23rd ACM international conference on Multimedia – MM '15. doi: <https://doi.org/10.1145/2733373.2806333>

19. Ordóñez F., Roggen D. Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition // Sensors. 2016. Vol. 16, Issue 1. P. 115. doi: <https://doi.org/10.3390/s16010115>